

Izvorni znanstveni članak | Original scientific paper | UDK: 551.46.07(497.5 Hvar)
Primljeno (Received): 28.11.2020.; Prihvaćeno (Accepted): 21.05.2021.

ANALIZE TEMPERATURA POVRŠINE MORA I ZRAKA MJERENIH NA TRI POSTAJE U HRVATSKOM DIJELU SREDNJEG JADRANA

dr. sc. Ognjen Bonacci, prof. emer.

Sveučilište u Splitu, Fakultet
građevinarstva, arhitekture i geodezije
Matice hrvatske 15, Split, Hrvatska
obonacci@gradst.hr

mr. sc. Duje Bonacci, dipl. ing. fiz.

Sveučilište u Zagrebu, Fakultet hrvatskih
studija
Borongajska cesta 83d, Zagreb, Hrvatska

dr. sc. Tanja Roje-Bonacci, prof. emer.

Sveučilište u Splitu, Fakultet
građevinarstva, arhitekture i geodezije
Matice hrvatske 15, Split, Hrvatska

Analizirani su nizovi srednjih mjesečnih i godišnjih temperatura površine mora izmjereni na tri postaje u hrvatskom dijelu srednjeg Jadrana: (1) Split (1960. - 2019.); (2) Hvar (1964. - 2019.); (3) Komiža (1991. - 2019.). S ciljem da se izuči odnos temperature površine mora i temperature zraka analizirane su i temperature zraka izmjerene na iste tri postaje u razdoblju 1960. - 2019. Primjenom RAPS metode ustanovljeno je postojanje naglog i statistički značajnog porasta temperatura površine mora na sve tri postaje počevši od 1998. godine. Statistički značajan porast temperature zraka na analiziranim postajama pojavio se nešto ranije, 1992. godine. Analizom mjesečnih vremenskih nizova temperature kako površine mora tako i zraka, utvrđen je trend porasta u svakom mjesecu godine s tim da je statistički značajan bio u razdoblju od travnja do kolovoza. Usporedbom višegodišnjih prosjeka srednjih mjesečnih temperatura zraka i temperatura površine mora ustanovljeno je da su u razdoblju od svibnja do kolovoza, na sve tri analizirane lokacije prosječne temperature površine mora niže od prosječnih temperatura zraka tijekom analiziranog razdoblja. Najveća razlika se javlja u srpnju kada su prosječne višegodišnje temperature zraka u Splitu i Hvaru više za 2,2 °C od prosječnih temperatura površine mora. U Komiži maksimalna razlika je nešto niža i iznosi 1,6 °C. U ostalim mjesecima godine prosječna temperatura površine mora viša je od prosječne temperature zraka. Najveća razlika se javlja u prosincu kada je na sve tri lokacije prosječna temperatura površine mora viša od prosječne temperature zraka za preko 5 °C.

Ključne riječi: temperatura površine mora, temperatura zraka, Mann-Kendall test, Split, Hvar, Komiža

1. UVOD

Površina Jadranskog mora iznosi 138.595 km², što predstavlja 4,6 % ukupne površine Sredozemnog mora čiji je Jadran najsjeverniji izdanak, najdublje uvučen u europsko kopno. Jadransko se more može tretirati kao prostrani zaljev središnjeg dijela Mediterana, odvojen od cjeline Apeninskim poluotokom (<https://sites.google.com/site/morskisvijetpetra/jadransko-more>). Sa Sredozemnim morem je povezano Otrantskim vratima širokim oko 70 km. Jadransko se more proteže u smjeru jugoistok-sjeverozapad duljinom od 870 km, od Maranske lagune u Italiji do ušća rijeke Butrint u Albaniji. Srednja širina mu iznosi oko 200 km.

Zbog utjecaja mnogobrojnih čimbenika u pogledu fizičkih, kemijskih i bioloških svojstava, Jadransko je more asimetrično (Viličić, 2013.). Prema dubini se dijeli na slijedeće tri sastavnice: (1) vrlo plitki sjeverni Jadran čija prosječna dubina iznosi 35 m; (2) srednji Jadran s prosječnom dubinom od 140 m; (3) južni Jadran s prosječnom dubinom od oko 300 m i maksimalnom dubinom od 1228 m izmjerenom u Južnojadranskoj kotlini (Viličić, 2014.). Hrvatskoj pripada najveći dio jadranskih obala. Ukupna duljinu obale na hrvatskom dijelu Jadrana procijenjena je na 5.835 km. Od toga na duljinu otočnih obala otpada 4.058 km ili 97,2 % od ukupnih duljina obala. Duljina kopnene obale Hrvatske iznosi 1.777 km (Viličić, 2014.).

Ključno je pitanje kako će klimatske promjene, a prije svega globalno zagrijavanje, utjecati na ekološke, ali i društvene procese u pojedinim regijama našeg planeta. Činjenica je da se klima različito mijenja na različitim dijelovima planeta i u različitim okolišima. Okoliš u kojem se susreću kopno i more posebno je složen jer su njegovi procesi istovremeno pod utjecajem kopnenih i vodenih masa koje različito reaguju na promjenu klime. Zbog složene geometrije i topografije svaki je zaljev, otok ili kanal na Jadranu i uz hrvatsku obalu specifičan po oceanografskim svojstvima (Orlić, 2001.), ali i po reakcijama na klimatske promjene (Bonacci i Ljubenkov, 2020.; Bonacci i sur. 2020.).

Krželj (2010.) je izučavajući više od 2.336.770 podataka iz različitih baza zaključila da je Jadransko more u razdoblju od kraja osamdesetih godina prošlog stoljeća pretrpjelo ozbiljne promjene u morskom ekosustavu. Činjenica je da se situacija s klimatskim promjenama i dalje intenzivira. Jedan od ključnih i neizbježnih preduvjeta za nalaženje brzih i učinkovitih odgovora na ugroze koje uzrokuju klimatske promjene u Jadranskom moru i njegovom okolišu je detaljno i istovremeno praćenje i analiza razvoja temperatura površine mora i zraka na raznim lokacijama ovog prostranog područja.

U članku su analizirana ponašanja mjesečnih i godišnjih nizova temperature površine mora i zraka mjerene na tri postaje u području srednjeg Jadrana: (1) Split; (2) Hvar na otoku Hvaru; (3) Komiža na otoku Visu. Izvršena je analiza statističke značajnosti trendova srednjih mjesečnih i godišnjih temperatura zraka izmjerenih na prethodno spomenutim meteorološkim

postajama. Naglašava se da je glavni cilj analiza izvršenih u ovom radu usmjeren na izučavanje ponašanja površinskih temperatura mora kao posljedica globalnih klimatskih promjena. Činjenica je da se u našoj literaturi, ali i u onoj međunarodnoj, relativno rijetko nailazi na radove koji analiziraju trendove površinskih temperatura mora, neusporedivo rjeđe nego na one koje analiziraju temperature zraka. Razlog je u biti vrlo jednostavan. Temperatura površine mora motri se na mnogo manje postaja nego temperatura zraka, a i nizovi mjerenja su mnogo kraći.

Vlahakis i Pollatou (1993.) naglašavaju da temperatura površine mora predstavlja ključni čimbenik pri procjeni klimatske strukture i razvoja klimatskih procesa, globalnih, regionalnih i osobito lokalnih na malim otocima i u priobalju. Bulgin i sur. (2020.) navode da ona izravno utječe ne samo na temperaturu zraka u tim područjima već i na ostale klimatske parametre i procese (globalni lateralni transport energije, radijacijsku i turbulentnu izmjenu energije između mora i zraka, modifikaciju atmosferskog graničnog sloja, oborine, evapotranspiraciju, vlagu u zraku i tlu, razvoj vjetrova, hidrološki ciklus itd.), a vezano s njima i na ekološke i društvene procese.

Treba napomenuti da temperatura površine mora nije tipičan meteorološki parametar. Iako se nalazi izvan atmosfere, njen utjecaj na procese u atmosferi je bitan. Termička su svojstva vode različita od onih kopnenih. Zbog prozračnosti vode, toplina koja dolazi zračenjem Sunca raspoređuje se na veći volumen vodene mase. Voda ima veći termički kapacitet od kopna pa se sporije grije i hladi od njega. More, za razliku od kopna ublažava temperaturu zraka tijekom zime i ljeta pa su rasponi ekstremnih površinskih temperatura mora znatno niži od raspona ekstremnih temperatura zraka na okolnom kopnu (Penzar i sur., 2001.). Pošto je voda fluid, strujanjem i procesima turbulencije voda se iz dubine i okoline miješa s onom na površini utječući na temperaturu zraka. Takvi procesi osobito snažno utječu na svekolike procese na malim otocima i priobalju. Uočeno je da temperatura zraka na različitim otocima i priobalnim prostorima različito reagira na površinsku temperaturu mora. Zbog toga, svaku pojedinu lokaciju treba individualno analizirati na osnovi detaljnih i pouzdanih motrenja.

Jadransko je more prepoznato kao prostor vrlo osjetljiv na klimatske promjene. Grbec i sur. (2015.) su izučavali kombinirani učinak recentnih promjena klime sjeverne hemisfere i lokalne klime Jadrana na ekosustav Jadranskog mora. U svom su radu ukazali na intenzitet promjena te objasnili glavne pokretače promjena ekosustava u Jadranskom moru.

Na malim otocima i u priobalju trendovi ponašanja i razvoja temperature zraka izravno zavise o temperaturama površine mora koje ih okružuje. Zbog toga je za ove prostore od bitnog značaja kvantificirati recentna vremenska ponašanja trendova i variranja površinske temperature mora te shvatiti njihovu interakciju s temperaturama zraka. Upravo to i predstavlja osnovni

zadatak ovog rada. Klimatske promjene koje se upravo zbivaju na Zemlji nisu zaobišle ni prostore Jadrana i zahtijevaju da se dublje istraže i da se bolje shvati kao prvo recentni razvoj površinskih temperatura mora, a potom i njihova interakcija s temperaturama zraka na malim otocima i u priobalju Jadranskog mora. Fizičke kao i društvene karakteristike malih otoka kao i priobalja hrvatskog dijela Jadranskog mora, ukazuju na to da su oni od strane klimatskih promjena potencijalno izrazito ranjivi. Devastacija okoliša i promjene u i onako relativno nepovoljnoj bilanci voda na ovim uglavnom krškim terenima, izazvane prije svega porastom temperatura površine mora i zraka, kao i podizanja razine mora, mogu uzrokovati brojne i drastične negativne ne samo ekološke već i socijalne posljedice.

2. MATERIJALI I METODE

2.1. Opis analiziranih lokacija

U tablici 1 upisane su osnovne karakteristike analiziranih postaja, tj. njihove geografske koordinate, nadmorska visina, H , vremenski nizovi mjerenih temperatura površine mora i zraka koji su obrađeni u ovom radu te zračna udaljenost između meteorološke postaje u kojoj se mjeri temperatura zraka i lokacije na kojoj se mjeri temperatura površine mora, L . U posljednjem retku u zagradama su naznačene vrijednosti najmanje zračne udaljenosti meteorološke postaje od morske obale. Karta s položajem tri analizirane lokacije nalazi se na slici 1 na kojoj su ucrtane i udaljenosti među njima.

Meteorološka postaja Split Marijan se nalazi na slabije naseljenom istočnom dijelu poluotoka u park-šumi Marijan. Lokacija je u neposrednoj blizini drugog po visini vrha brežuljka Marijana čija najviša kota iznosi 178 metara nad morem (m n.m.). Grad Split ima 178.192 stanovnika prema popisu izvršenom 2011. godine. Iako se radi o snažnoj urbanoj aglomeraciji koja se brzo širi, zbog svog položaja na brežuljku Marijan u području zaštićenog parka prirode, meteorološka postaja nije pod značajnijim utjecajem procesa urbanizacije. Temperatura površine mora mjeri se na vrhu lukobrana koji se nalazi na najistočnijem rubu splitskog poluotoka.

Tablica 1: Osnovne karakteristike tri analizirane postaje

	SPLIT	HVAR	KOMIŽA
geografska širina	43° 30' 30"	43° 10' 16"	43° 02' 54"
geografska dužina	16° 25' 35"	16° 26' 13"	16° 05' 07"
H (mnm)	122	20	20
raspoloživi podaci temperature mora	1960. - 2019.	1964. - 2019.	1991. - 2019.
obrađeni podaci temperature zraka	1960. - 2019.	1960. - 2019.	1960. - 2019.
L (m)	3100 (515)	100 (80)	190 (175)



Slika 1: Karta tri analizirane postaje s ucrtanim udaljenostima među njima

Otok Hvar pripada skupini srednjodalmatinskih otoka. S površinom od 297,38 km², i dužinom obale od 270 km, Hvar je četvrti po veličini otok na hrvatskom dijelu Jadranskog mora (Duplančić Leder i sur., 2004.). Grad Hvar ima 4251 stanovnika prema popisu iz 2011. godine. Meteorološka postaja je smještena u malom šumarku, dislocirana od središta grada. Temperatura mora se mjeri na vrhu malog mulića udaljenog od meteorološke postaje 100 m.

Otok Vis jedan je od hrvatskih otoka najudaljenijih od kopna koji je stoga izložen snažnim vjetrovima. S površinom od 89,72 km², i duljinom obale od 85 km, Vis je deveti po veličini otok na hrvatskom dijelu Jadranskog mora (Duplančić Leder i sur., 2004.). Meteorološka postaja Vis nalazi se u gradu Komizi, na sjevernom rubu urbaniziranog područja. Gradić Komiza je lociran na zapadnom dijelu otoka te ima 1526 stanovnika prema popisu iz 2011. godine. Pošto se vodom snabdijeva iz vlastitog krškog vodonosnika ovaj bi otok mogao biti osobito ugrožen klimatskim promjenama (porastom temperatura zraka i podizanjem razine mora (Bonacci i sur., 2020.). Temperatura površine mora mjeri se na kraju gradskog lukobrana.

Prema Köppen-Geiger klasifikaciji analizirano se područje nalazi u Csa tipu klime (Šegota i Filipčić, 2003.). Radi se o semiaridnoj varijanti mediteranske klime koja se ponekad naziva i „klima maslina“, a karakteriziraju ju blage, vlažne i kišne zime te suha i topla (često i vruća) ljeta.

2.2. Korišteni podaci

U analizama izvršenim u ovom radu korišteni su službeni podaci Državnog hidrometeorološkog zavoda

iz Zagreba na čemu im se ovom prilikom najljepše zahvaljujemo.

Obradeni su svi raspoloživi podaci srednjih dnevnih temperatura površine mora izmjereni na tri odabrane lokacije. Najduži raspoloživi niz od 60 godina (1960. – 2019.) postoji na postaji Split. Na postaji Hvar niz je nešto kraći te iznosi 56 godina (1964. – 2019.), dok je na postaji Komiža najkraći i obuhvaća razdoblje od 29 godina (1991. – 2019.). Konvencionalni način mjerenja temperature površine mora obavlja se pomoću termometra uronjenog na dubini od oko 30 cm na reprezentativnom mjestu gdje voda nije plića od 1,8 m. Termometar se na toj dubini zadržava tri minute. Zatim ga se izvadi i brzo očita, vodeći računa da se pri čitanju ne učini pogreška zbog paralakse (Pandžić, 2008.). Temperatura površine mora se mjeri u ista tri termina kada se mjeri i temperatura zraka, dakle u 7, 14 i 21 sat po srednjem lokalnom vremenu.

Temperature zraka su mjerene na tri glavne meteorološke postaje državnog hidrometeorološkog zavoda. Zanimljivo je da je meteorološka postaja Hvar započela s radom 1858. godine, a meteorološka postaja Split Marijan godinu dana kasnije. Svjetska meteorološka organizacija je prepoznala kvalitetu hvarske postaje. Dodijelila joj je status stoljetne postaje, proglašivši je nezamjenjivom intelektualnom baštinom čovječanstva. Meteorološka postaja Komiža započela je s radom 1959. godine. U radu su analizirani vremenski nizovi srednjih mjesečnih i godišnjih temperatura zraka na sve tri postaje u razdoblju od 1960. do 2019. godine.

U Hrvatskoj kao i u većini srednjoeuropskih zemalja, koristi se slijedeći izraz za računanje srednje dnevne temperature površine mora i zraka, T_{sr} :

$$T_{sr} = (T_7 + T_{14} + 2 \times T_{21})/4 \quad (1)$$

kod čega, T_7 , T_{14} i, T_{21} , predstavljaju temperature mjerene u 7, 14, i 21 sat.

2.3. Metode statističke analize

Linearni i nelinearni (krivulja drugog reda) trendovi su proračunavani za vremenske nizove srednjih, mjesečnih i godišnjih temperatura površine mora i zraka za tri analizirane postaje. Jednadžba linearnog trenda glasi:

$$T = (a \times t) + b \quad (2)$$

dok za nelinearni trend glasi:

$$T = (c \times t^2) + (d \times t) + e \quad (3)$$

kod čega, T , predstavlja srednju, mjesečnu ili godišnju temperaturu u godini, t , dok su, a , b , koeficijenti linearne regresije, c , d , e , koeficijenti krivulje drugog reda. Svih pet koeficijenata proračunava se metodom najmanjih kvadrata. Koeficijent, a , predstavlja nagib pravca regresije čija je dimenzija °C godišnje. Kao takav on je

indikator prosječnog intenziteta trenda podizanja ili opadanja vrijednosti analiziranog vremenskog niza. Za linearne trendove izračunate su i u radu navedene kvadratne vrijednosti koeficijenata linearne korelacije, r^2 , dok su za krivulje drugog reda izračunate i navedene kvadratne vrijednosti indeksa nelinearne korelacije, R^2 . I koeficijent linearne korelacije kao i indeks nelinearne korelacije predstavljaju mjeru jačine i smjera linearne i nelinearne veze između varijabli x (vremena) i y (srednje mjesečne ili godišnje temperature površine mora ili zraka). Predznak koeficijenta linearne korelacije ukazuje na smjer linearne veze. Negativna vrijednost označava da je trend u opadanja, dok pozitivna vrijednost ukazuje na trend u porastu.

Statistička značajnost linearnih trendova provjeravana je *Mann-Kendall* (M-K) neparametarskim testom. U radu je korišten je *pyMannKendall package for Python*. (Hussain Shourov i Mahmud, 2019.). Nulta hipoteza za ovaj test je da ne postoji monotoni trend u analiziranom vremenskom nizu. Alternativna hipoteza je da trend postoji. U ovom radu kao kriterij za prihvatanje alternativne hipoteze (postojanje statistički značajnog linearnog trenda) korištena je vrijednost vjerojatnosti, $p < 0,05$.

Za određivanje statistički značajnih pojava skokova ili padova vrijednosti unutar analiziranih vremenskih nizova u radu je korištena *Rescaled Adjusted Partial Sums* (RAPS) metoda (Garbrecht i Fernandez, 1994.; Bonacci i Roje-Bonacci, 2020.). Ova metoda omogućava da se zanemare slučajne promjene i greške unutar vremenskih nizova te da se jasno uoče nagle promjene (skokovi ili opadanja) analiziranih vrijednosti. Na osnovu toga određuju se podrazdoblja sa statistički značajno različitim prosječnim vrijednostima analizirane varijable.

Za određivanje statističke značajnosti razlika između prosječnih vrijednosti dva susjedna podrazdoblja definirana RAPS metodom, korišteni su F-test i t-test (McGhee, 1985.). U radu je F-testom ispitivana jednakost varijanci dvije normalno raspodijeljene populacije (dva podskupa), dok se t-test koristio za kvantitativnu procjenu da li se prosječne vrijednosti dva vremenska podskupa statistički značajno razlikuju. U oba testa kao nivo za prihvatanje hipoteze da se prosječne vrijednosti podnizova statistički značajno razlikuju, izabrana je vrijednost vjerojatnosti od, $p < 0,05$.

U radu je korišten i postupak autokorelacije. Autokorelacija se naziva i serijskom korelacijom. Ona ukazuje na povezanost signala s kopijom. Autokorelacija je matematička prezentacija stupnja sličnosti između određenog vremenskog niza i njegovih sukcesivno vremenski pomaknutih verzija u uzastopnim vremenskim intervalima. U ovom radu su proračuni vršeni s vremenskim intervalima od godinu dana. Postupak proračuna je identičan kao u slučaju računanja linearne korelacije između bilo koja dva niza. Jedina je razlika što se kod postupka autokorelacije uvijek koristi isti niz, s tim da se onaj drugi niz stalno pomiče za jedan ili više perioda. Vrijednosti koeficijenata autokorelacije, r , govore

o tome koliko su snažne unutrašnje veze analiziranog niza. U praksi se često koristi termin "pamćenje sustava", koji označava razdoblje do trenutka kada vrijednosti koeficijenta autokorelacije postaju beznačajne. Smatra se da je to trenutak kada su vrijednosti koeficijenta autokorelacije manje od, $r=0,2$ (Mangin, 1984.).

3. REZULTATI I RASPRAVA

U okviru ovog poglavlja analizirat će se promjene srednjih, godišnjih i mjesečnih vrijednosti temperatura površine mora i zraka tijekom vremena na osnovi raspoloživih podataka. Nažalost, vremenski nizovi mjerenih temperatura površine mora na tri analizirane postaje nisu identični što će donekle utjecati na mogućnost pouzdane usporedbe rezultata dobivenih na tri analizirane lokacije. Dobro je da se u razdoblju recentnih 29 godina (1991. – 2019.), kada je uočen najintenzivniji porast temperatura kako površine mora tako i zraka, raspolaze s mjerenjima na sve tri lokacije. Ta će činjenica omogućiti da se mogu donijeti nešto pouzdaniji zaključci o recentnom, ali potencijalno i budućem ponašanju temperatura u analiziranom području.

3.1. Analiza srednjih godišnjih temperatura površine mora i zraka

U [tablici 2](#) iznesene su vrijednosti osnovnih statističkih karakteristika (minimumi, prosjeci, maksimumi i rasponi) srednjih godišnjih temperatura mora, T_M , temperatura

zraka, T_Z , i njihove razlike, $\Delta T = T_M - T_Z$, opaženih na tri analizirane postaje. U [tablici 3](#) unesene su vrijednosti kvadrata koeficijenata linearne korelacije, r^2 , između parova nizova srednjih godišnjih vrijednosti temperatura površine mora mjerenih na tri analizirane postaje za razdoblja kad postoje mjereni podaci na obje postaje. Uočavaju se vrlo visoke vrijednosti što ukazuje na sličnost ponašanja srednjih godišnjih temperatura površine mora u analiziranom području. Najmanja vrijednost je između međusobno najudaljenijih postaja Split i Komiža, a najveća između Hvara i Komiže. U [tablici 4](#) unesene su vrijednosti kvadrata koeficijenata linearne korelacije, r^2 , između parova nizova srednjih godišnjih vrijednosti temperatura zraka mjerenih na tri analizirane postaje za razdoblja 1960. – 2019. Uočavaju se vrlo visoke vrijednosti što ukazuje na sličnost ponašanja srednjih godišnjih temperatura zraka u analiziranom području. Najmanja vrijednost je između postaja Hvara i Komiže, a najveća između Hvara i Splita.

Grafički prikaz vremenskih nizova srednjih godišnjih temperatura površine mora, T_M , na tri analizirane postaje prikazani su na [slici 2](#). Ucertani su i pravci regresije te krivulje drugog reda s pripadnim kvadratima koeficijenata linearne korelacije, r^2 , i indeksa nelinearne korelacije, R^2 . Osim toga su upisane i vrijednosti vjerojatnosti M-K testa, p . Na sve tri analizirane lokacije M-K test pokazuje da postoje statistički značajni linearni trendovi porasta temperature površine mora pošto su vrijednosti vjerojatnosti, $p < 0.01$. Treba uočiti da se u slučaju Splita

Tablica 2: Osnovne statističke karakteristike srednjih godišnjih temperatura površine mora, T_M , temperatura zraka, T_Z , i njihove razlike, $\Delta T = T_M - T_Z$, opažene na tri analizirane postaje

T (°C)		SPLIT	HVAR	KOMIŽA
		1960. - 2019.	1964. - 2019.	1991. - 2019.
TM	minimum	16,3 (1978.)	17,0 (1978.)	17,9 (1991.)
	prosjeak	17,43	18,09	18,86
	maksimum	18,7 (2018.)	19,3 (2018.)	19,5 (2018.)
	raspon	2,4	2,3	1,6
TZ	minimum	15,1 (1978.)	15,5 (1980.)	16,2 (1991.)
	prosjeak	16,37	16,72	17,17
	maksimum	17,8 (2014.)	18,2 (2018.)	18,0 (1994.)
	raspon	2,7	2,7	1,8
ΔT	minimum	1,2	1,5	1,7
	prosjeak	1,06	1,37	1,69
	maksimum	0,9	1,1	1,5
	raspon	-0,3	-0,4	-0,2

Tablica 3: Matrica kvadrata koeficijenta linearne korelacije, r^2 , između parova nizova srednjih godišnjih vrijednosti temperatura površine mora mjerenih na tri analizirane postaje za razdoblja kad postoje mjereni podaci na obje postaje


r2	SPLIT	HVAR	KOMIŽA
SPLIT	1	0,8695	0,7510
HVAR		1	0,8725
KOMIŽA			1

Tablica 4: Matrica kvadrata koeficijenta linearne korelacije, r^2 , između parova nizova srednjih godišnjih vrijednosti temperatura zraka mjerenih na tri analizirane postaje u razdoblju 1960. - 2019.


r2	SPLIT	HVAR	KOMIŽA
SPLIT	1	0,9574	0,8157
HVAR		1	0,8062
KOMIŽA			1

i Hvara nizovi ne ponašaju linearno već im se mnogo bolje prilagođava krivulja drugog reda. U slučaju Komiže, zbog kratkoće niza, tj. nepostojanja mjerenja prije 1991. godine, takvo ponašanje nije bilo moguće utvrditi.

Grafički prikaz na [slici 2](#) upućuje da su srednje godišnje temperature površine mora u snažnom porastu tek od kraja devedesetih godina prošlog stoljeća. Korištenjem RAPS metode utvrđeno je da na sve tri lokacije postoje slijedeća dva podniza: (1) do uključivo 1997.; (2) 1998. - 2019. Grafički prikazi ovih podnizova su dati na [slici 3](#). Na njoj su ucrtani pravci regresije (trendovi) te su upisane i prosječne vrijednosti temperature površine mora kao i vjerojatnosti M-K testa, p . Na sve tri analizirane lokacije, bez obzira na različitu dužinu prvog podniza (do uključivo 1997. godine), uočeno je da trendovi porasta u prvom podrazdoblju nisu statistički značajni. Što više, u slučaju Splita trend je statistički neznačajno opadajući. U drugom podrazdoblju od 1998. do 2019. na sve tri postaje trendovi pokazuju porast. Najveći je u Splitu, potom na Hvaru, gdje su trendovi i statistički značajni jer je, $p < 0,05$. Najmanji i statistički neznačajan porast je u Komiži. Matrica rezultata prosječnih vrijednosti podnizova srednjih godišnjih temperatura površine mora, T_{M^*} , u dva podrazdoblja određena RAPS metodom



Slika 2 Nizovi srednjih godišnjih temperatura površine mora, T_M , opaženi na tri analizirane postaje: (1) Split (1960. - 2019.; plava boja); (2) Hvar (1964. - 2019.; zelena boja); (3) Komiža (1991. - 2019.; crvena boja)




Slika 3 Podnizovi srednjih godišnjih temperatura površine mora, T_M , opaženi na tri analizirane postaje definirani RAPS metodom: (1) Split (plava boja); (2) Hvar (zelena boja); (3) Komiža (crvena boja)

na tri analizirane postaje s vrijednostima vjerojatnosti, p , F-testa i t-testa između susjednih podrazdoblja dana je u [tablici 5](#). Prema rezultatima t-testa vidljivo je da se u sva tri slučaja prosječne vrijednosti u dva uzastopna podrazdoblja statistički značajno razlikuju na razini vjerojatnosti, $p < 0,01$. Rezultati F-testa potvrđuju da se varijance između susjednih podnizova ne razlikuju statistički značajno.


Grafički prikaz vremenskih nizova srednjih godišnjih temperatura zraka, T_Z , na tri analizirane postaje u razdoblju 1960. - 2019. prikazani su na [slici 4](#). Ucertani su i pravci regresije te krivulje drugog reda s pripadnim kvadratima koeficijenta linearne korelacije, r^2 , i indeksa nelinearne korelacije, R^2 . Osim toga su upisane i vrijednosti

Tablica 5: Matrica rezultata prosječnih vrijednosti podnizova srednjih godišnjih temperatura površine mora, T_{M^*} , u dva podrazdoblja određena RAPS metodom na tri analizirane postaje te vrijednosti vjerojatnosti, p , F-testa i t-testa između susjednih podrazdoblja

Postaja	Podrazdoblje	TMpr (°C)	p (F-test)	p (t-test)
SPLIT	1960. - 1997.	17,19	0,5654	2,8E-07
	1998. - 2019.	17,85		
HVAR	1964. - 1997.	17,77	0,7877	7,7E-13
	1998. - 2019.	18,58		
KOMIŽA	1991. - 1997.	18,35	0,4780	2,0E-05
	1998. - 2019.	19,02		



Slika 4 Nizovi srednjih godišnjih temperatura zraka, T_{zr} , opaženi u razdoblju 1960. - 2019. na tri analizirane postaje: (1) Split (plava boja); (2) Hvar (zelena boja); (3) Komiža (crvena boja)



Slika 5 Podnizovi srednjih godišnjih temperatura zraka, T_{zr} , opaženi na tri analizirane postaje definirani RAPS metodom: (1) Split (plava boja); (2) Hvar (zelena boja); (3) Komiža (crvena boja)

vjerojatnosti M-K testa, p . Na sve tri analizirane lokacije M-K test pokazuje da postoje statistički značajni linearni trendovi porasta temperature zraka pošto su vrijednosti vjerojatnosti, $p < 0,01$. Treba uočiti da se na sve tri meteorološke postaje nizovi ne ponašaju linearno već im se mnogo bolje prilagođava krivulja drugog reda. Ovakvo ponašanje temperatura zraka uočeno je kod nizova temperatura zraka izmjerenih na brojnim meteorološkim postajama u Hrvatskoj i na području zapadnog Balkana (Bonacci 2010., 2012.; Bonacci i Roje-Bonacci 2020.; Pandžić i sur., 2020.).

Grafički prikaz na **slici 4** ukazuje da su srednje godišnje temperature zraka u snažnom porastu tek početkom devedesetih godina prošlog stoljeća. Korištenjem RAPS metode utvrđeno je da na sve tri lokacije postoje slijedeća dva podniza: (1) 1960. - 1991.; (2) 1992. - 2019. Grafički prikazi ovih podnizova su dani na **slici 5**. Na njoj su ucrtani pravci regresije (trendovi) te su upisane i prosječne vrijednosti temperature zraka kao i vjerojatnosti M-K testa, p . Na sve tri analizirane lokacije, M-K test sugerira da trendovi u prvom podrazdoblju (1960. - 1991.) nisu statistički značajni. Štoviše, u slučaju Splita i Hvara trendovi su statistički neznačajno opadajući. U drugom podrazdoblju od 1992. do 2019. na sve tri postaje trendovi pokazuju porast. Najveći je u Splitu, potom na Hvaru, gdje su trendovi statistički značajni jer je, $p < 0,01$. Najmanji i statistički neznačajan trend porasta je u Komiži. Matrica rezultata prosječnih vrijednosti podnizova srednjih godišnjih temperatura zraka, T_{zr} u dva podrazdoblja određena RAPS metodom


na tri analizirane postaje s vrijednostima vjerojatnosti, p , F-testa i t-testa između susjednih podrazdoblja prikazana je u **tablici 6**. Prema rezultatima t-testa vidljivo je da se u sva tri slučaja prosječne vrijednosti u dva uzastopna podrazdoblja statistički značajno razlikuju na razini vjerojatnosti, $p < 0,01$. Rezultati F-testa ukazuju da se varijance između susjednih podnizova temperatura zraka Splita i Hvara razlikuju statistički značajno na razini, $p < 0,05$, dok se na postaji Komiža statistički značajno ne razlikuju. Važno je zaključiti da je nagli porast srednjih godišnjih temperatura zraka započeo šest godina ranije od porasta srednjih godišnjih temperatura površine mora.

Vrijednost kvadrata koeficijenta linearne korelacije između srednjih godišnjih temperatura mora i temperatura zraka Splita za razdoblje 1960. - 2019. iznosi, $r^2 = 0,6883$, za Hvar u razdoblju 1964. - 2019., $r^2 = 0,7959$, dok za Komižu u razdoblju 1991. - 2019. iznosi, $r^2 = 0,6183$. Uočljivo najčvršći odnos je na Hvaru dok je najslabiji na Komiži.


Na **slici 6** ucrtani su autokorelogrami nizova srednjih godišnjih temperatura površine mora u Splitu (plava boja) i Hvaru (zelena boja), te nizova srednjih godišnjih temperatura zraka u Splitu (modra boja) i Hvaru (tamno zelena boja). Kako bi ih se moglo uspoređivati za definiranje autokorelograma nizova srednjih godišnjih temperatura površine mora i zraka na lokaciji Splita su korišteni nizovi 1960. - 2019., a na lokaciji Hvara nizovi 1964. - 2019. Zbog kratkoće niza mjerenja temperatura mora Komiže za tu postaju nisu izračunati autokorelogrami. Zanimljivo je uočiti da na lokaciji

Tablica 6: Matrica rezultata prosječnih vrijednosti podnizova srednjih godišnjih temperatura zraka, T_{zr} u dva podrazdoblja određena RAPS metodom na tri analizirane postaje te vrijednosti vjerojatnosti, p , F-testa i t-testa između susjednih podrazdoblja

Postaja	Podrazdoblje	T_{zr} (°C)	p (F-test)	p (t-test)
SPLIT	1960. - 1991	15,98	0,6642	3,4E-11
	1992. - 2019.	17,03		
HVAR	1960. - 1991.	16,40	0,4149	1,6E-10
	1992. - 2019.	17,26		
KOMIŽA	1960. - 1991.	16,45	0,3314	7,8E-09
	1992. - 2019.	17,26		



Slika 6 Autokorelogrami, tj. nizovi koeficijenta linearne autokorelacije, r , temperature površine mora izmjerene u Splitu (plava boja), Hvaru (svijetlo zelena boja) i temperature zraka Splita (modra boja) i Hvara (tamno zelena boja)



Slika 7 Histogrami prosječnih srednjih mjesečnih temperatura površine mora, T_{MORE} (modra boja), temperature zraka, T_{ZRAK} (smeđa boja) i njihove razlike, $\Delta T = T_{MORE} - T_{ZRAK}$ (crna boja) opaženih u Splitu u razdoblju 1960. - 2019.

Hvara autokorelogrami temperature površine mora i zraka pokazuju slično ponašanje. Na lokaciji Splita autokorelogram niza srednjih godišnjih temperatura zraka gotovo je identičan onome za Hvar. Međutim, autokorelogram niza srednjih godišnjih temperatura površine mora Splita bitno se razlikuje. Nakon vrijednosti, $\Delta T = 7$ godina, vrijednost koeficijenta autokorelacije, r , pada ispod 0,2, tj. vrijednosti tzv. „pamćenja sustava“. Očito je da je u ovom slučaju unutrašnja struktura niza slabija nego u ostala tri analizirana niza kod kojih minimalna vrijednost koeficijenta autokorelacije nije pala ispod vrijednosti 0,2.

3.2. Analiza srednjih mjesečnih temperatura površine mora i zraka

U prethodnom potpoglavlju analizirana su ponašanja nizova srednjih godišnjih temperatura površine mora i zraka. Primjenom kraće vremenske skale od mjesec dana u ovom će se potpoglavlju analizirati kako se srednje mjesečne temperature površine mora i zraka ponašaju na tri postaje tijekom pojedinih mjeseci godine.


U **tablici 7** nalaze se vrijednosti osnovnih statističkih karakteristika (minimumi, prosjeci, maksimumi i rasponi) srednjih mjesečnih temperatura mora, T_M temperatura zraka, T_Z i njihove razlike, $\Delta T = T_M - T_Z$, opažene na lokaciji Splita u razdoblju 1960. - 2019. Žutom podlogom označeni su negativne vrijednosti razlike, ΔT , za sve četiri analizirane karakteristike. Žutom podlogom označeni su dakle slučajevi kada je temperatura zraka, T_Z , viša od temperature površine mora, T_M . Kod minimalnih mjesečnih vrijednosti to se desilo samo tijekom tri mjeseca, od svibnja do srpnja. Kod prosječnih mjesečnih vrijednosti ta je pojava zapažena od travnja do kolovoza, dok je kod maksimalnih mjesečnih vrijednosti opažena od travnja do rujna. Rasponi između srednjih mjesečnih temperatura zraka u svim su mjesecima veći nego rasponi između srednjih mjesečnih temperatura površine mora. Na **slici 7** grafički su prikazani histogrami prosječnih srednjih mjesečnih temperatura površine mora, T_{MORE} (modra boja), temperature zraka, T_{ZRAK} (smeđa boja) i njihove razlike, $\Delta T = T_{MORE} - T_{ZRAK}$ (crna boja) opaženih u Splitu u razdoblju 1960. - 2019.

Tablica 7: Osnovne statističke karakteristike srednjih mjesečnih temperatura mora, T_M temperatura zraka, T_Z i njihove razlike, $\Delta T = T_M - T_Z$, opažene u Splitu u razdoblju 1960. - 2019.


T (°C)		Sij.	Velj.	Ožu.	Tra.	Svi.	Lip.	Srp.	Kol.	Ruj.	Lis.	Stu.	Pro.
TM	minimum	10,2	10	10,7	12,6	15	19,2	21,5	21,3	19,5	17	14,6	12,2
	prosjeak	12,36	11,68	12,14	14,13	17,62	21,44	23,44	23,77	21,92	19,60	16,85	14,22
	maksimum	14,4	13,7	14	16	21,5	23,4	25,7	26,1	24,6	21,6	18,7	16,5
	raspon	4,2	3,7	3,3	3,4	6,5	4,2	4,2	4,8	5,1	4,6	4,1	4,3
TZ	minimum	4,3	4,1	6,0	10,6	15,4	20,9	23,3	21,2	17,8	12,8	8,9	5,8
	prosjeak	7,89	8,41	10,88	14,39	19,14	23,32	26,09	25,80	21,46	17,19	12,72	9,17
	maksimum	11,2	12,0	13,7	18,0	22,7	28,0	29,5	29,2	25,4	19,2	15,8	11,2
	raspon	6,9	7,9	7,7	7,4	7,3	7,1	6,2	8,0	7,6	6,4	6,9	5,4
ΔT	minimum	5,9	5,9	4,7	2,0	-0,4	-1,7	-1,8	0,1	1,7	4,2	5,7	6,4
	prosjeak	4,47	3,27	1,26	-0,26	-1,53	-1,89	-2,64	-2,03	0,46	2,41	4,13	5,05
	maksimum	3,2	1,7	0,3	-2,0	-1,2	-4,6	-3,8	-3,1	-0,8	2,4	2,9	5,3
	raspon	-2,7	-4,2	-4,4	-4,0	-0,8	-2,9	-2,0	-3,2	-2,5	-1,8	-2,8	-1,1

U **tablici 8** nalaze se vrijednosti osnovnih statističkih karakteristika (minimumi, prosjeci, maksimumi i rasponi) srednjih mjesečnih temperatura mora, T_M , temperatura zraka, T_z , i njihove razlike, $\Delta T = T_M - T_z$, opažene na lokaciji Hvara u razdoblju 1964. - 2019. Žutom podlogom označene su negativne vrijednosti razlika, ΔT , za sve četiri prikazane karakteristike. Žutom podlogom označeni su slučajevi kada je temperatura zraka, T_z , viša od temperature površine mora, T_M . Kod minimalnih mjesečnih vrijednosti to se desilo samo tijekom tri mjeseca, od svibnja do srpnja. Kod prosječnih mjesečnih vrijednosti ta je pojava zapažena od svibnja do kolovoza, dok je kod maksimalnih mjesečnih vrijednosti opažena od travnja do rujna. Rasponi između srednjih mjesečnih temperatura zraka u svim su mjesecima veći nego rasponi između srednjih mjesečnih temperatura površine mora. Na **slici 8** grafički su prikazani histogrami prosječnih srednjih mjesečnih temperatura površine mora, T_{MORE} (modra boja), temperature zraka, T_{ZRAK} (smeđa boja) i njihove razlike, $\Delta T = T_{MORE} - T_{ZRAK}$ (crna boja) opaženih u Hvaru u razdoblju 1964. - 2019.

U **tablici 9** nalaze se vrijednosti osnovnih statističkih karakteristika (minimumi, prosjeci, maksimumi i rasponi) srednjih mjesečnih temperatura mora, T_M , temperatura zraka, T_z , i njihove razlike, $\Delta T = T_M - T_z$, opažene na lokaciji Komiže u razdoblju 1991. - 2019. Žutom podlogom označene su negativne vrijednosti razlika, ΔT , za sve četiri prikazane karakteristike. Radi se o slučajevima kada je temperatura zraka, T_z , viša od temperature površine mora, T_M . Kod minimalnih mjesečnih vrijednosti to se desilo samo tijekom tri mjeseca, od lipnja do kolovoza. Kod prosječnih mjesečnih vrijednosti ta je pojava zapažena od svibnja do kolovoza, dok je kod maksimalnih mjesečnih vrijednosti opažena od travnja do kolovoza. Rasponi između srednjih mjesečnih temperatura zraka u svim su mjesecima veći nego rasponi između srednjih mjesečnih temperatura površine mora. Na **slici 9** grafički su prikazani histogrami prosječnih srednjih mjesečnih



Slika 8 Histogrami prosječnih srednjih mjesečnih temperatura površine mora, T_{MORE} (modra boja), temperature zraka, T_{ZRAK} (smeđa boja) i njihove razlike, $\Delta T = T_{MORE} - T_{ZRAK}$ (crna boja) opaženih u Hvaru u razdoblju 1964. - 2019.



Slika 9 Histogrami prosječnih srednjih mjesečnih temperatura površine mora, T_{MORE} (modra boja), temperature zraka, T_{ZRAK} (smeđa boja) i njihove razlike, $\Delta T = T_{MORE} - T_{ZRAK}$ (crna boja) opaženih u Komiži u razdoblju 1991. - 2019.

temperatura površine mora, T_{MORE} (modra boja), temperature zraka, T_{ZRAK} (smeđa boja) i njihove razlike, $\Delta T = T_{MORE} - T_{ZRAK}$ (crna boja) opaženih u Komiži u razdoblju 1991. - 2019.


Usporedbom višegodišnjih prosjeka srednjih mjesečnih temperatura zraka i temperature površine mora ustanovljeno je da je u razdoblju od svibnja do

Tablica 8: Osnovne statističke karakteristike srednjih mjesečnih temperatura mora, T_M , temperatura zraka, T_z , i njihove razlike, $\Delta T = T_M - T_z$, opažene u Hvaru u razdoblju 1964. - 2019.

	T (°C)	Sij.	Velj.	Ožu.	Tra.	Svi.	Lip.	Srp.	Kol.	Ruj.	Lis.	Stu.	Pro.
T_M	minimum	12,5	11,2	11,6	13,0	15,6	19,0	20,7	21,7	20,2	18,2	16,0	14,2
	prosjeak	13,60	12,71	12,95	14,57	17,62	21,20	23,19	23,70	22,62	20,72	18,24	15,61
	maksimum	15,6	14,5	14,8	16,2	21,2	23,5	25,1	25,6	24,8	22,3	20,3	17,2
	raspon	3,1	3,3	3,2	3,2	5,6	4,5	4,4	3,9	4,6	4,1	4,3	3,0
T_z	minimum	5,5	5,3	7,1	11,2	15,8	20,4	23,3	21,5	18,4	14,4	10,6	7,2
	prosjeak	9,02	9,32	11,37	14,41	18,79	22,75	25,44	25,19	21,73	17,87	13,82	10,40
	maksimum	12,1	12,6	14,4	17,3	21,6	26,5	28,2	28,0	25,0	19,8	16,9	12,2
	raspon	6,6	7,3	7,3	6,1	5,8	6,1	4,9	6,5	6,6	5,4	6,3	5,0
ΔT	minimum	7,0	5,9	4,5	1,8	-0,2	-1,4	-2,6	0,2	1,8	3,8	5,4	7,0
	prosjeak	4,58	3,39	1,58	0,16	-1,17	-1,55	-2,25	-1,50	0,89	2,85	4,42	5,20
	maksimum	3,5	1,9	0,4	-1,1	-0,4	-3,0	-3,1	-2,4	-0,2	2,5	3,4	5,0
	raspon	-3,5	-4,0	-4,1	-2,9	-0,2	-1,6	-0,5	-2,6	-2,0	-1,3	-2,0	-2,0

Tablica 9: Osnovne statističke karakteristike srednjih mjesečnih temperatura mora, T_M , temperatura zraka, T_Z , i njihove razlike, $\Delta T = T_M - T_Z$, opažene u Komiži u razdoblju 1991. - 2019.

T (°C)		Sij.	Velj.	Ožu.	Tra.	Svi.	Lip.	Srp.	Kol.	Ruj.	Lis.	Stu.	Pro.
T_M	minimum	13,3	12,8	12,7	14,1	15,9	19,9	22,8	22,7	20,5	19,2	16,9	14,7
	prosjeak	14,50	13,82	14,18	15,35	18,28	22,07	24,33	24,87	22,92	20,89	18,54	16,23
	maksimum	16,0	15,1	15,3	16,8	20,5	23,9	25,7	26,5	24,8	22,1	19,8	17,7
	raspon	2,7	2,3	2,6	2,7	4,6	4,0	2,9	3,8	4,3	2,9	2,9	3,0
T_Z	minimum	6,3	6,8	9,7	11,3	15,7	21,7	24	23,6	18,6	16,3	11,8	8,2
	prosjeak	9,80	9,79	11,88	14,77	19,11	23,34	25,97	25,99	21,77	18,19	14,47	11,09
	maksimum	12,5	12,8	15,2	17,1	21,2	26,7	27,8	28,7	24,7	20	16,7	13
	raspon	6,2	6	5,5	5,8	5,5	5	3,8	5,1	6,1	3,7	4,9	4,8
ΔT	minimum	7,0	6,0	3,0	2,8	0,2	-1,8	-1,2	-0,9	1,9	2,9	5,1	6,5
	prosjeak	4,69	4,03	2,30	0,58	-0,83	-1,27	-1,63	-1,12	1,15	2,70	4,08	5,14
	maksimum	3,5	2,3	0,1	-0,3	-0,7	-2,8	-2,1	-2,2	0,1	2,1	3,1	4,7
	raspon	-3,5	-3,7	-2,9	-3,1	-0,9	-1,0	-0,9	-1,3	-1,8	-0,8	-2,0	-1,8

**Slika 9** Histogrami prosječnih srednjih mjesečnih temperatura površine mora, T_{MORE} (modra boja), temperature zraka, T_{ZRAK} (smeđa boja) i njihove razlike, $\Delta T = T_{MORE} - T_{ZRAK}$ (crna boja) opaženih u Komiži u razdoblju 1991. - 2019.

kolovoza, na sve tri analizirane lokacije prosječna temperatura površine mora niža od prosječnih temperatura zraka tijekom analiziranih razdoblja. Jedino je u Splitu prosječna temperatura mora u analiziranom razdoblju (1960. - 2019.) i u travnju niža od temperature zraka. Najveća razlika se javlja u srpnju kada su prosječne višegodišnje temperature zraka u Splitu više za 2,64 °C. U Hvaru u razdoblju 1964. - 2019. u srpnju su više za 2,25 °C od prosječnih temperatura površine mora. U Komiži, maksimalna razlika je u srpnju te iznosi 1,63 °C. U ostalim mjesecima godine, prosječna temperatura površine mora viša je od prosječne temperature zraka. Najveća razlika se javlja u prosincu kada je na sve tri lokacije prosječna temperatura površine mora viša od prosječne temperature zraka za preko 5 °C.

Uspoređujući rezultate na sve tri lokacije, moguće je uočiti veliku sličnost u ponašanju s tim da je apsolutno pouzdane zaključke nemoguće donijeti zbog različitih duljina analiziranih nizova. Bez obzira na taj nedostatak, kao pouzdan zaključak nameće se da su karakteristične temperature zraka više od temperatura mora tijekom

toplog dijela godine. Čini se da se najmanje razlike javljaju na lokaciji Komiže, a najveće na lokaciji Splita. Razlozi za to dijelom se mogu tražiti u različitim duljinama vremenskih nizova, ali na njih utječu i lokalni čimbenici (udaljenost i položaj meteorološke postaje od lokacije na kojoj se mjeri temperatura mora) kao i oni regionalni (udaljenost lokacije od kopnene mase).

U tablici 10 unesene su vrijednosti kvadrata koeficijenta linearne korelacije (linearnih trendova), r^2 , i vjerojatnost M-K testa, p , za raspoložive vremenske nizove srednjih mjesečnih nizova temperature površine mora opažene na tri analizirane postaje. Rezultati uneseni u ovu tablicu potvrđuju da se statistički značajni porasti temperatura površine mora zbivaju u toplom dijelu godine. Činjenica je da se oni javljaju tijekom svih 12 mjeseci na Hvaru, dok je u Splitu ta pojava prisutna tek od ožujka do kolovoza. Na Komiži je situacija manje jasna jer se statistički značajni trendovi porasta javljaju u travnju, lipnju, srpnju, rujnu i prosincu, ali ne i u svibnju i kolovoza.

U tablici 11 unesene su vrijednosti kvadrata koeficijenta linearne korelacije (linearnih trendova), r^2 , i vjerojatnost M-K testa, p , za raspoložive vremenske nizove srednjih mjesečnih nizova temperature zraka opažene na tri analizirane postaje u razdoblju 1960. - 2019. U slučaju nizova srednjih mjesečnih temperatura zraka ponašanje je gotovo identično na sve tri postaje. Statistički značajni trendovi porasta javljaju se na sve tri postaje od ožujka do kolovoza, ali u Splitu i Komiži i u prosincu.

Na osnovi prethodno iznesenih analiza, zaključak je da na tri analizirane lokacije, a moguće i na cijelom Jadranskom moru i njegovom priobalju, temperature površine mora i zraka imaju najjači intenzitet porasta tijekom toplog razdoblja godine. Ovaj se zaključak u cijelosti slaže s rezultatima koji su izneseni u radu Bartolini i sur. (2012.). Analizirajući karakteristične

Tablica 10: Matrica vrijednosti kvadrata koeficijenta linearne korelacije (linearnih trendova), r^2 , i vjerojatnost M-K testa, p , za raspoložive vremenske nizove srednjih mjesečnih podataka temperature površine mora opažene na tri analizirane postaje

Postaja	SPLIT		HVAR		KOMIŽA	
Razdoblje	1960. - 2019.		1964. - 2019.		1991. - 2019.	
	r^2	p	r^2	p	r^2	p
Siječanj	0,0214	0,4587	0,1952	0,0027	0,0927	0,1376
Veljača	0,0685	0,1732	0,1612	0,0041	0,0983	0,2207
Ožujak	0,1290	0,0101	0,2223	0,0008	0,1508	0,0618
Travanj	0,1212	0,0029	0,2762	7,5E-05	0,4687	7,5E-05
Svibanj	0,1090	0,0305	0,2166	0,0013	0,0696	0,3095
Lipanj	0,1636	0,0027	0,2952	4,5E-05	0,1140	0,0369
Srpanj	0,2178	0,0001	0,3617	7,4E-06	0,2204	0,0160
Kolovoz	0,1155	0,0095	0,2726	0,0002	0,0327	0,3475
Rujan	0,0472	0,0717	0,1148	0,0092	0,0809	0,0349
Listopad	0,0298	0,1133	0,0875	0,0368	0,0002	0,8203
Studenj	0,0339	0,1401	0,1279	0,0064	0,0984	0,0678
Prosinac	0,0239	0,1367	0,1923	0,0016	0,2431	0,0088

Brojevi upisani modrom bojom označavaju da je vjerojatnost M-K testa, $0,01 < p < 0,05$

Brojevi upisani crvenom bojom označavaju da je vjerojatnost M-K testa, $p < 0,01$

Tablica 11: Matrica vrijednosti kvadrata koeficijenta linearne korelacije (linearnih trendova), r^2 , i vjerojatnost M-K testa, p , za vremenske nizove srednjih mjesečnih podataka temperature zraka opažene na tri analizirane postaje u razdoblju 1960. - 2019.


Postaja	SPLIT		HVAR		KOMIŽA	
	r^2	p	r^2	p	r^2	p
Siječanj	0,0448	0,1474	0,0187	0,3784	0,0566	0,1009
Veljača	0,0207	0,3043	0,0115	0,4630	0,0263	0,2779
Ožujak	0,0866	0,0381	0,0797	0,0398	0,0867	0,0374
Travanj	0,1523	0,0012	0,1203	0,0011	0,1311	0,0026
Svibanj	0,0893	0,0145	0,1152	0,0035	0,1030	0,0115
Lipanj	0,3201	1,2E-05	0,3295	8,6E-08	0,3171	3,9E-06
Srpanj	0,4028	9,4E-07	0,4701	6,9E-08	0,3954	4,1E-07
Kolovoz	0,2663	5,3E-05	0,3366	3,1E-06	0,3087	5,2E-06
Rujan	0,0209	0,2559	0,0461	0,0970	0,0422	0,1091
Listopad	0,0406	0,1698	0,0185	0,3922	0,0419	0,2034
Studenj	0,0539	0,1036	0,0313	0,1841	0,0752	0,0501
Prosinac	0,0556	0,0450	0,0075	0,3509	0,0633	0,0398

Brojevi upisani modrom bojom označavaju da je vjerojatnost M-K testa, $0,01 < p < 0,05$

Brojevi upisani crvenom bojom označavaju da je vjerojatnost M-K testa, $p < 0,01$

temperature zraka opažene na 21 meteorološkoj postaji u razdoblju 1995. - 2007. na području Mediterana, u regiji Toskane (Italija), autori su ustanovili da se najbrži intenzitet porasta temperatura zraka javlja od ožujka do kolovoza.

Na slici 10 grafički su prikazani odnosi između prosječnih vrijednosti srednjih mjesečnih temperatura površine mora, $T_{M,mjesec}$, i temperatura zraka, $T_{Z,mjesec}$ Splita (plava boja), Hvara (zelena boja) i Komiže (crvena boja) opaženih u razdoblju 1991. - 2019. Uočava se formiranje sličnih, ali ne i identičnih petlji na sve tri analizirane lokacije. Rezultati ovog prikaza dobiveni na osnovu analize podataka istog razdoblja (1991. - 2019.) za sve tri lokacije potvrđuju prethodne zaključke donesene na osnovi različitih duljina vremenskih nizova.



Slika 10 Odnosi između prosječnih vrijednosti srednjih mjesečnih temperatura površine mora, $T_{M,mjesec}$, i temperatura zraka, $T_{Z,mjesec}$ Splita (plava boja), Hvara (zelena boja) i Komiže (crvena boja) opaženih u razdoblju 1991. - 2019.

4. ZAKLJUČNO RAZMATRANJE

U radu je utvrđeno da su trendovi temperatura mora i zraka na analizirane tri lokacije u porastu. Intenzivni porast temperatura zraka započeo je nešto ranije (1992.) nego porast temperature mora (1998.). Očito je da se naša obala i otoci moraju vrlo ozbiljno pripremiti na daljnje poraste temperatura koji bi mogli značajno utjecati na prirodne, ali i društvene procese ovih vrlo ranjivih prostora.

Krželj (2010.) navodi slijedeće: „Na Jadranu je u proteklih 40 godina primijećen porast temperature, povećano zakiseljavanje, promjene u količini oborina, dotoku vode i hranjivih tvari rijekom Po te zbog toga povećanje saliniteta u sjevernom dijelu Jadrana. Osim toga primijećena je i promjena u geografskoj rasprostranjenosti pojedinih organizama, npr. termofilne vrste riba i meduza. Primijećene su promjene u sastavu i brojnosti i ostalog zooplanktona, posebno u obalnom dijelu Jadranskog mora. Osim horizontalnih migracija, prisutne su i vertikalne migracije prema dubljim i hladnijim vodama te će se, ukoliko temperatura mora i dalje nastavi rasti, geografska rasprostranjenost ovih vrsta sve više smanjivati i na kraju će potpuno nestati. Zabilježena su i sve češća toksična cvjetanja morskog fitoplanktona, širenje bakterija i termofilnih vrsta tropskih algi preko balastnih voda.“ Klimatski modeli predviđaju da će se klimatske promjene nastaviti događati istim tempom ili čak ubrzanije što znači da je realno pretpostaviti da će i negativne promjene u Jadranu i njegovom priobalju biti još izraženije. Uz ostale, prije svega sve intenzivnije antropogene, prijetnje morskom okolišu, poput pretjeranog ulova, onečišćenja, devastacije obalnih staništa, pritiska turizma, istraživanja i eksploatacije ugljikohidrata itd., negativne posljedice mogle bi biti još drastičnije.

Nedostatak pouzdanih pokazatelja klimatskih promjena, a prije svega temperatura površine mora i zraka, značajno utječu na donošenje učinkovitih mjera koje bi

trebale ublažiti negativne učinke (Al Sayah i sur., 2020.). Ograničeni resursi krških otoka i priobalja hrvatskog dijela Jadrana u kombinaciji s nedovoljno kontroliranim i stoga vrlo često neodrživim antropogenim aktivnostima (npr. masovnim turizmom, prenamjenom korištenja zemljišta, pretjeranim crpljenjem podzemne vode, urbanizacijom, apartmanizacijom itd.) značajno utječu na reduciranje opcija za adaptaciju na postojeće i buduće klimatske promjene. Zbog izvanrednog povijesnog i socijalnog značaja kao i biološke autentičnosti i ranjivosti, cijeli Mediteran zahtijeva poduzimanje žurnih i učinkovitih integralnih mjera koje će biti sposobne osigurati njegov održivi razvoj. U tom je smislu bitno detaljnije izučiti interakciju temperatura površine mora i temperatura zraka te predvidjeti njihov razvoj u budućnosti. Problem je što Hrvatska, kao uostalom i većina zemlja Mediterana, ne raspolaže s dovoljno gustom mrežom mjernih postaja i dovoljno dugim nizovima mjerenja, prije svega, temperatura površine mora. Bitno je shvatiti da različite lokacije otoka i priobalja vrlo različito reagiraju na globalne klimatske promjene. Razlozi su brojni, a najčešći su udaljenost otoka od kontinenta te njihova lokalna i regionalna topografija terena.

Autori se nadaju da će ovaj rad pridonijeti boljem razumijevanju tretirane problematike, te da će inicirati interdisciplinarnu suradnju s kolegama iz drugih znanstvenih disciplina s ciljem da u našim uvjetima započne intenzivnije i koordinirano interdisciplinarno izučavanje ove složene i za našu državu izrazito važne problematike.

Zahvala

Ovaj rad je sufinanciran kroz projekt "VODIME - Vode Imotske krajine" (KK.05.1.1.02.0024), projekt financiran sredstvima Vlade Republike Hrvatske i sredstvima Europske unije kroz Europski strukturni fond, u sklopu poziva "Shema za jačanje primijenjenih istraživanja za mjere prilagodbe klimatskim promjenama" (KK.05.1.1.02.).

LITERATURA:

- Al Sayah, M. J., Abdallah, C., Khouri, M., Nedjai, R., Darwich, T. (2020.): A framework for climate change assessment in Mediterranean data-sparse watersheds using remote sensing and ARIMA modeling. *Theoretical and Applied Climatology*, 143, (1-2), DOI:10.1007/s00704-020-03442-7
- Bartolini, G., di Stefano, V., Maracchi, G., Orlandini, S. (2012.): Mediterranean warming is especially due to summer season – Evidences from Tuscany (central Italy). *Theoretical and Applied Climatology*, 107 (1-2), 279–295. DOI:10.1007/s00704-011-0481-1
- Bonacci, O. (2010.): Analiza nizova srednjih godišnjih temperatura zraka u Hrvatskoj. *Građevinar*, 62(9), 781–791.
- Bonacci, O. (2012.): Increase of mean annual surface air temperature in the Western Balkans during last 30 years. *Vodoprivreda*, 44 (255–257), 75–89.
- Bonacci, O., Ljubenkov, I. (2020.): Različite vrijednosti i trendovi temperatura zraka na dvije postaje na malom otoku: slučaj meteoroloških postaja Korčula i Vela Luke na otoku Korčuli. *Hrvatske Vode*, 28 (113), 183–196.
- Bonacci, O., Patekar, M., Polo, M., Roje-Bonacci, T. (2020.): Analyses of climate variations at four meteorological stations on remote islands in the Croatian part of the Adriatic Sea. *Atmosphere*, 11 (10), 1044. DOI:10.3390/atmos11101044
- Bonacci, O., Roje-Bonacci, T. (2020.): Primjena metode dan za danom (*day to day*) varijabilnosti temperature zraka na podacima opaženim na opservatoriju Zagreb-Grič (1887.–2018.). *Hrvatske Vode*, 28 (112), 125–134
- Bulgin, C. E., Merchant, C. J., Ferreira, D. (2020.): Tendencies, variability and persistence of sea surface temperature anomalies. *Scientific Report*, 10, 7986. DOI:10.1038/s41598-020-64785-9
- Duplančić Leder, T., Ujević, T., Čala, M. (2004.): Coastline lengths and areas of islands in the Croatian part of the Adriatic Sea determined from the topographic maps at the scale 1:25,000. *Geoadria*, 9 (1), 5–32.
- Garbrecht, J., Fernandez, G. P. (1994.): Visualization of trends and fluctuations in climatic records. *Water Resources Bulletin*, 30 (2), 297–306. DOI:10.1111/j.1752-1688.1994.tb03292.x
- Grbec, B., Morović, M., Matić, F., Ninčević Gladan, Ž., Marasović, I., Vidjak, O., Bojanić, N., Čikeš Keč, V., Zorica, B., Kušpilić, G., Matić-Skoko, S. (2015.): Climate regime shifts and multi-decadal variability of the Adriatic Sea pelagic ecosystem. *Acta Adriatica*, 56 (1), 47–66.
- Husain Shourov, M. M., Mahmud, I. (2019.): pyMannKendall: a python package for non parametric Mann Kendall family of trend tests. *Journal of Open Source Software*, 4 (9), 1556. DOI:10.21105/joss.01556
- Krželj, M. (2010.): Utjecaj klimatskih promjena na morski okoliš. *Paediatrica Croatica*, 54 (1), 18–23.
- Mangin, A. (1984.): Pour une meilleure connaissance des systemes hydrologiques a partir des analyses correlative et spectrale. *Journal of Hydrology*, 67 (1-4), 25–43.
- McGhee, J. W. (1985.): *Introductory statistics*. West Publishing Company, St Paul and New York.
- Orlić, M. (2001.): Croatian coastal waters. In: Cushman-Roisin, B., Gačić, M., Poulain, P.-M., Artegiani, A. (eds.), *Physical oceanography of the Adriatic Sea: past, present and future*, 189–214. Kluwer Academic Publishers, Dordrecht, Neederlands.
- Pandžić, K. (urednik) (2008.): *Naputak za opažanja i mjerenja na glavnim meteorološkim postajama*. Državni hidrometeorološki zavod, Zagreb.
- Pandžić, K., Kobold, M., Oskoruš, D., Biondić, B., Biondić, R., Bonacci, O., Likso, T., Curić, O. (2020.): Standard normal homogeneity test as a tool to detect change points in climate-related river discharge variation: case study of the Kupa River Basin. *Hydrological Sciences Journal*. 65 (2), 227–241. DOI:10.1080/02626667.2019.1686507
- Penzar, B., Penzar, I., Orlić, M. (2001.): *Vrijeme i klima hrvatskog Jadrana*. Nakladna kuća „Dr. Feletar“, Zagreb.
- Šegota, T., Filipčić, A. (2003.): Köppenova podjela klima i hrvatsko nazivlje. *Geoadria*, 8 (1), 17–37.
- Viličić, D. (2013.): Jadran i globalne promjene. *Priroda*, 13 (7-8), 22–28.
- Viličić, D. (2014.): Specifična oceanološka svojstva hrvatskog dijela Jadrana. *Hrvatske Vode* 22 (90), 297–314.
- Vlahakis, G. N., Pollatou, R. S. (1993.): Temporal variability and spatial distribution of Sea Surface Temperatures in the Aegean Sea. *Theoretical and Applied Climatology*, 47 (1), 15–23. DOI:10.1007/BF00868892
<https://sites.google.com/site/morskisvijetpetra/jadransko-more> (posjet 17. svibnja 2021.)

BATHING QUALITY OF THE SEA IN THE PRIMORJE-GORSKI KOTAR COUNTY AND IN THE RIJEKA AREA IN THE PAST DECADE

Abstract. We analysed the series of mean monthly and annual temperatures of the sea surface measured at three stations in the Croatian part of the Central Adriatic: (1) Split (1960 -2019), (2) Hvar (1964 -2019) and (3) Komiža (1991-2019). In order to study the relation between sea surface temperature and air temperature, we also analysed air temperatures measured at the same three stations in the period from 1960 to 2019. The applied RAPS method revealed the existence of a sudden, statistically significant increase in sea surface temperatures at all three stations starting from 1998. A statistically significant increase in air temperatures at the analysed stations occurred slightly earlier, in 1992. An analysis of monthly time series of both sea surface temperatures and air temperatures showed an upward trend for each month of the year and was statistically significant for the period from April to August. A comparison of multi-annual averages of mean monthly air and sea surface temperatures showed that average sea surface temperatures were lower than average air temperatures in the period from May to August at all three analysed locations. The largest difference occurs in July, when average multi-annual air temperatures in Split and Hvar are 2.2°C higher than average sea surface temperatures. In Komiža, the maximum difference is slightly lower, i.e. 1.6°C. In the remaining months of the year, average sea surface temperatures are higher than average air temperatures. The greatest difference occurs in December, with average sea surface temperature by over 5°C higher than average air temperature at all three locations.

Key words: sea surface temperature, air temperature, the Mann-Kendall test, Split, Hvar, Komiža

BADEWASSERQUALITÄT IN DER GESPANSCHAFT PRIMORJE-GORSKI KOTAR UND IM BEZIRKRIJEKA IM LETZTEN JAHRZEHN

Zusammenfassung. Die Zeitreihen von Monats- und Jahresmittelwerten der Meeresoberflächentemperaturen wurden analysiert, die an den folgenden drei Stationen an der kroatischen Mitteladria gemessen wurden: (1) Split (1960-2019), (2) Hvar (1964-2019) und (3) Komiža (1991-2019). Mit dem Ziel, das Verhältnis zwischen Meeresoberflächentemperatur und Lufttemperatur zu untersuchen, wurden auch die an den drei Stationen im Zeitraum 1960-2019 gemessenen Lufttemperaturen analysiert.

Mit Hilfe der RAPS-Methode (rescaled adjusted partial sums) konnte ein rascher und statistisch signifikanter Anstieg der Meeresoberflächentemperaturen an allen drei Stationen ab dem Jahr 1998 festgestellt werden. Der statistisch signifikante Anstieg der Lufttemperaturen trat eigentlich an den Stationen etwas früher an, nämlich in 1992. Die Analyse von monatlichen Lufttemperaturzeitreihen der Meeresoberflächentemperatur und der Lufttemperatur zeigte, dass sich ein Anstiegstrend in jedem Monat des Jahres abzeichnete, wobei er im Zeitraum von April bis August statistisch signifikant war. Der Vergleich zwischen den mehrjährigen Monatsmittelwerten von Luft- und Meeresoberflächentemperaturen zeigte, dass im Zeitraum von Mai bis August an allen drei analysierten Stationen der Mittelwert der Meeresoberflächentemperatur niedriger als das Lufttemperaturmittel im gleichen Zeitraum war. Der größte Unterschied wurde im Juli festgestellt, wenn die durchschnittlichen mehrjährigen Lufttemperaturen in Split und Hvar um 2,2 Grad Celsius höher als die durchschnittlichen Meeresoberflächentemperaturen waren. In Komiža war der maximale Unterschied etwas niedriger und betrug 1,6 Grad Celsius. In den restlichen Monaten des Jahres war das Meeresoberflächentemperaturmittel höher als das Lufttemperaturmittel. Der größte Unterschied konnte im Dezember festgestellt werden, wenn an allen drei Stationen das Meeresoberflächentemperaturmittel um über 5 Grad Celsius höher als das Lufttemperaturmittel war.

Schlüsselwörter: Meeresoberflächentemperatur, Lufttemperatur, Mann-Kendall Trendtest, Split, Hvar, Komiža